PATENT ABSTRACTS OF JAPAN

(11)Publication number:

2002-108846

(43)Date of publication of application: 12.04.2002

(51)Int.Cl.

G06F 17/21 G06K 9/03 GO6K

(21)Application number: 2000-294877

(71)Applicant: FUJI XEROX CO LTD

(22)Date of filing:

27.09.2000

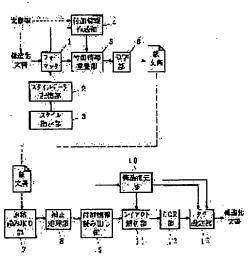
(72)Inventor: SUZUKI KAZUHIRO

(54) DEVICE/METHOD FOR PROCESSING DOCUMENT IMAGE AND RECORDING MEDIUM

(57)Abstract:

PROBLEM TO BE SOLVED: To provide a document image processor capable of restoring structured document after turning the structured document into a printable image.

SOLUTION: When a formatter 1 formats the structured data in accordance with style data, the formatter 1 sends its positional information to an additive information preparing part 4. The part 4 makes the positional information correspondent to document structure to turn the information and a document type to be additive information, an additive information superimposing part 5 superimposes it to a document image, and a printing part 6 prints it. A printed paper document is read by a document reading part 7. After it is correctly processed by a correcting processing part 8, the additive information is separated by an additive information reading part 9. A structure restoring part 10 restores document structure based on the additive information. A layout | analytic part 11 analyzes layout to segment a document element and recognizes a text by an OCR part 12. Then, a tag setting part 13 inserts the document element to the document structure restored by the part 10 to restore the structured document.



LEGAL STATUS

[Date of request for examination]

[Date of sending the examiner's decision of rejection]

[Kind of final disposal of application other than the examiner's decision of rejection or application converted registration]

[Date of final disposal for application]

[Patent number]

[Date of registration]

[Number of appeal against examiner's decision of rejection]

[Date of requesting appeal against examiner's decision of rejection]

[Date of extinction of right]

(19)日本国特許庁 (JP)

(n)公開特許公報 (A)

(11)特許出願公開番号 特開2002—108846

(P2002-108846A) (43)公開日 平成14年4月12日(2002.4.12)

(51) Int. Cl.	7	識別記号		FΙ				テ ーマコート'	(参考)
G06F 1	17/21	530		G06F	17/21	530	T	5B009	
		566 ·				566	P	5B029	
G06K	9/03			G06K	9/03		J	5B064	
	9/20	340		•	9/20	340	C	5C076	
						340	В		
			審查請求	未請求	請求項の数22	OL	(全15	頁) 最終頁	こ続く

(21)出願番号

特願2000-294877(P2000-294877)

(22)出願日

平成12年9月27日(2000.9.27)

(71)出願人 000005496

富士ゼロックス株式会社

東京都港区赤坂二丁目17番22号

(72)発明者 鈴木 一弘

神奈川県海老名市本郷2274番地 富士ゼロ

ックス株式会社内

(74)代理人 100101948

弁理士 柳澤 正夫

Fターム(参考) 5B009 NA05 NA06

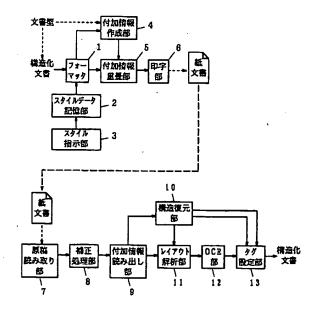
5B029 AA01 BB02 CC26 CC27 5B064 AA01 BA01 CA08 FA07 FA15 5C076 AA14 AA16 AA17 BA06

(54) 【発明の名称】文書画像処理装置、文書画像処理方法、および記録媒体

(57)【要約】

【課題】 構造化文書を印刷可能なイメージとした後に、構造化文書を復元することができる文書画像処理装置を提供する。

【解決手段】 フォーマッタ1がスタイルデータに従って構造化文書をフォーマットするときに、その位置情報を付加情報作成部4は、その位置情報と文書構造とを対応付け、その情報及び文書型を付加情報として付加情報重量部5で文書イメージに重量して印字部6で印字する。印字された紙文書は原稿読み取り部7で読み取り、補正処理部8で補正処理後、付加情報読み出し部9で付加情報を分離する。構造復元部10は、付加情報をもとに文書構造を復元する。一方、レイアウト解析部11はレイアウト解析して文書表を切り出し、テキストをOCR部12で認識する。そして、タグ設定部13で文書要素を構造復元部10で復元した文書構造に挿入し、構造化文書を復元する。



【特許請求の範囲】

【請求項1】 論理構造を持った構造化文書にレイアウ トを施して印刷可能とする文書画像処理装置において、 論理構造に対応する体裁情報を定義したスタイルデータ を記憶するスタイルデータ記憶手段と、前記スタイルデ ータに基づいて構造化文書にレイアウトを施して印刷処 理に適合した第1の印刷イメージに成形するとともに前 記構造化文書の文書要素の意味もしくは構造を識別する ための識別子と前記文書要素が前記第1の印刷イメージ 内に占める領域情報を生成する成形手段と、前記論理構 10 造を表す論理構造情報に加えて前記構造化文書の文書要 素の意味もしくは構造を識別するための識別子と前記文 書要素が前記第1の印刷イメージ内に占める領域情報の 対応関係を示す付加情報を生成する付加情報作成手段 と、前記第1の印刷イメージに前記付加情報を重畳して 第2の印刷イメージを生成する付加情報重畳手段を備え たことを特徴とする文魯画像処理装置。

1

【請求項2】 構造化文書の論理構造を表す論理構造情 報に加えて前記構造化文書の文書要素の意味もしくは構 造を識別するための識別子と前記文書要素が印刷イメー 20 ジ内に占める領域情報の対応関係を示す付加情報が重畳 された印刷イメージを読み取る文書画像処理装置におい て、前記印刷イメージを読み取り画像情報に変換する読 み取り手段と、前記画像情報から前記付加情報を読み出 す付加情報読み出し手段と、前記付加情報から前記論理 構造情報を得て前記論理構造を復元するとともに前記構 造化文書の文書要素の意味もしくは構造を識別するため の識別子と前記文書要素が前記印刷イメージ内に占める 領域情報の対応関係を得て前記識別子と前記識別子に対 応する前記領域情報を出力する構造復元手段と、前記画 30 像情報のレイアウトを認識して文字情報の含まれる領域 である文字プロックを抽出して前記領域情報に対応する 前記文字プロックを出力するレイアウト解析手段と、前 記文字プロック内の文字を認識してテキストデータを出 力する文字認識手段と、前記論理構造を得るとともに前 記識別子に対応する文魯要素位置に前記テキストデータ を挿入して構造化文書を得るタグ設定手段を備えたこと を特徴とする文書画像処理装置。

【請求項3】 さらに、前記読み取り手段で読み取った 前記画像情報に対して傾き補正または天地補正を施して 40 補正画像情報を得る補正手段を有し、前記付加情報読み 出し手段は、前記補正画像情報から前記付加情報を読み 出すものであり、前記レイアウト解析手段は、前記補正 画像情報のレイアウトを認識するものであることを特徴 とする請求項2に記載の文書画像処理装置。

【請求項4】 前記論理構造情報は、構造化文書の文書 型であることを特徴とする請求項1ないし請求項3のい ずれか1項に記載の文譽画像処理装置。

【請求項5】 前記論理構造情報は、構造化文書の特定

する請求項1ないし請求項3のいずれか1項に記載の文 書画像処理装置。

【請求項6】 前記印刷イメージ内に占める前記領域情 報は、前記印刷イメージ内に設定された座標系によって 記述されることを特徴とする請求項1ないし請求項3の いずれか1項に記載の文書画像処理装置。

【請求項7】 前記印刷イメージ内に占める前記領域情 報は、前記印刷イメージ内の領域に対して一意に識別可 能な符号を所定の手順で割り当てたものであることを特 徴とする請求項1ないし請求項3のいずれか1項に記載 の文魯画像処理装置。

【請求項8】 前記構造化文書の文書要素の意味もしく は構造を識別するための識別子と前記文書要素が前記第 1の印刷イメージ内または前記印刷イメージ内に占める 領域情報の対応関係は、印刷イメージの生成側と読取側 とで共有していることを特徴とする請求項1ないし請求 項3のいずれか1項に記載の文魯画像処理装置。

【請求項9】 前記構造化文書の文書要素の意味もしく は構造を識別するための識別子と前記文書要素が前記印 刷イメージ内に占める領域情報の対応関係は、前記論理 構造を階層表記し、前記文書要素を前記第1の印刷イメ ージ内に占める領域情報に置き換えて記述したものであ ることを特徴とする請求項1ないし請求項3のいずれか 1項または請求項6または請求項7に記載の文書画像処 理装置。

【請求項10】 論理構造を持った構造化文書にレイア ウトを施して印刷可能とする文書画像処理装置におい て、前記論理構造に対応してあらかじめ定義されたスタ イルデータを記憶したスタイルデータ記憶手段と、前記 スタイルデータに基づいて構造化文書にレイアウトを施 して第1の印刷イメージに成形するとともに前記論理構 造と前記レイアウト情報の組み合わせを同定する組み合 わせ情報を生成する成形手段と、前記組み合わせ情報を 付加情報とする付加情報作成手段と、前記第1の印刷イ メージに前記付加情報を重畳して第2の印刷イメージを 生成する付加情報重量手段を備えたことを特徴とする文 書画像処理装置。

【請求項11】 構造化文書の論理構造とレイアウト情 報の組み合わせを同定する組み合わせ情報が付加情報と して重畳された印刷イメージを読み取る文書画像処理装 置において、前記印刷イメージを読み取り画像情報に変 換する読み取り手段と、前記画像情報から前記付加情報 を読み出す付加情報読み出し手段と、前記付加情報から 前記組み合わせ情報を得て予め設定されている前記論理 構造と前記レイアウト情報の定義に基づいて前記構造化 文書の文書要素の意味もしくは構造を識別するための識 別子と前記文書要素が前記印刷イメージ内に占める領域 情報の対応関係を得て前記識別子と前記識別子に対応す る前記領域情報を出力する構造復元手段と、前記画像情 の文書型に対応付けられた識別情報であることを特徴と 50 報のレイアウトを認識して文字情報の含まれる領域であ

3

る文字ブロックを抽出し前記領域情報に対応する前記文字ブロックを出力するレイアウト解析手段と、前記文字ブロック内の文字を認識してテキストデータを出力する文字認識手段と、前記論理構造を得るとともに前記識別子に対応する文書要素位置に前記テキストデータを挿入して前記構造化文書を得るタグ設定手段を備えたことを特徴とする文書画像処理装置。

【請求項12】 さらに、前記読み取り手段で読み取った前記画像情報に対して傾き補正または天地補正を施して補正画像情報を得る補正手段を有し、前記付加情報院 10 み出し手段は、前記補正画像情報から前記付加情報を読み出すものであり、前記レイアウト解析手段は、前記補正画像情報のレイアウトを認識するものであることを特徴とする請求項11に記載の文書画像処理装置。

【請求項13】 前記付加情報は、前記印刷イメージに可視に重畳されていることを特徴とする請求項1ないし請求項12のいずれか1項に記載の文書画像処理装置。 【請求項14】 前記付加情報は、前記印刷イメージに不可視に重畳されていることを特徴とする請求項1ないし請求項12のいずれか1項に記載の文書画像処理装置。

【請求項15】 論理構造を持った構造化文書にレイアウトを施して印刷可能とする文書画像処理方法において、論理構造に対応する体裁情報を定義したスタイルデータに基づいて構造化文書にレイアウトを施して印刷処理に適合した第1の印刷イメージに成形するとともに、前記構造化文書の文書要素の意味もしくは構造を識別するための識別子と前記文書要素が前記第1の印刷イメージ内に占める領域情報を生成し、前記論理構造を表す論理構造情報に加えて前記構造化文書の文書要素の意味も30しくは構造を識別するための識別子と前記文書要素が前記第1の印刷イメージ内に占める領域情報の対応関係を示す付加情報を生成して前記第1の印刷イメージに重量し、第2の印刷イメージを生成することを特徴とする文書画像処理方法。

【請求項16】 構造化文書の論理構造を表す論理構造情報に加えて前記構造化文書の文書要素の意味もしくは構造を識別するための識別子と前記文書要素が印刷イメージ内に占める領域情報の対応関係を示す付加情報が重量された印刷イメージを読み取る文書画像処理方法において、前記印刷イメージを読み取って画像情報に変換し、前記画像情報から前記付加情報を語み出し、前記付加情報から前記論理構造情報を得て前記論理構造を復元するとともに、前記構造化文書の文書要素の意味もしくは構造を識別するための識別子と前記文書要素が前記印刷イメージ内に占める領域情報の対応関係を得て前記識別子と前記識別子に対応する前記領域情報を取得し、前記画像情報のレイアウトを認識して文字情報の含まれる領域である文字ブロック内の文字を認識してテキストデー 50

タとし、前記論理構造を得るとともに前記識別子に対応 する文書要素位置に前記テキストデータを挿入して構造 化文書を得ることを特徴とする文書画像処理方法。

4

【請求項17】 論理構造を持った構造化文書にレイアウトを施して印刷可能とする文書画像処理方法において、前記論理構造に対応してあらかじめ定義されたスタイルデータに基づいて構造化文書にレイアウトを施して第1の印刷イメージに成形するとともに、前記論理構造と前記レイアウト情報の組み合わせを同定する組み合わせ情報を生成して付加情報とし、該付加情報を前記第1の印刷イメージに重畳して第2の印刷イメージを生成することを特徴とする文書画像処理方法。

【請求項18】 構造化文書の論理構造とレイアウト情 報の組み合わせを同定する組み合わせ情報が付加情報と して重畳された印刷イメージを読み取る文書画像処理方 法において、前記印刷イメージを読み取って画像情報に 変換し、前記画像情報から前記付加情報を読み出して前 記付加情報から前記組み合わせ情報を取得し、予め設定 されている前記論理構造と前記レイアウト情報の定義に 基づいて前記構造化文書の文書要素の意味もしくは構造 を識別するための識別子と前記文書要素が前記印刷イメ ージ内に占める領域情報の対応関係を得て前記識別子と 前記識別子に対応する前記領域情報を取得し、前記画像 情報のレイアウトを認識して文字情報の含まれる領域で ある文字プロックを抽出し、前記領域情報に対応する前 記文字プロック内の文字を認識してテキストデータを取 得し、前記論理構造を得るとともに前記識別子に対応す る文書要素位置に前記テキストデータを挿入して前記構 造化文書を得ることを特徴とする文書画像処理方法。

【請求項19】 論理構造を持った構造化文書にレイア ウトを施して印刷可能とする文書画像処理をコンピュー 夕に実行させるプログラムを格納したコンピュータ読取 可能な記憶媒体において、論理構造に対応する体裁情報 を定義したスタイルデータに基づいて構造化文書にレイ アウトを施して印刷処理に適合した第1の印刷イメージ に成形するとともに前記構造化文書の文書要素の意味も ・しくは構造を識別するための識別子と前記文書要素が前 記第1の印刷イメージ内に占める領域情報を生成する成 形処理と、前記論理構造を表す論理構造情報に加えて前 記構造化文書の文書要素の意味もしくは構造を識別する ための識別子と前記文書要素が前記第1の印刷イメージ 内に占める領域情報の対応関係を示す付加情報を生成す る付加情報作成処理と、前記第1の印刷イメージに前記 付加情報を重畳して第2の印刷イメージを生成する付加 情報重畳処理をコンピュータに実行させるプログラムを 格納したコンピュータ読取可能な記憶媒体。

別子と前記識別子に対応する前記領域情報を取得し、前 記画像情報のレイアウトを認識して文字情報の含まれる 領域である文字ブロックを抽出し、前記領域情報に対応 する前記文字ブロック内の文字を認識してテキストデー 50 ージ内に占める領域情報の対応関係を示す付加情報が重

畳された印刷イメージを読み取る文書画像処理をコンピ ュータに実行させるプログラムを格納したコンピュータ **読取可能な記憶媒体において、前記印刷イメージを読み** 取り画像情報に変換する読み取り処理と、前記画像情報 から前記付加情報を読み出す付加情報読み出し処理と、 前記付加情報から前記論理構造情報を得て前記論理構造 を復元するとともに前記構造化文書の文書要素の意味も しくは構造を識別するための識別子と前記文書要素が前 記印刷イメージ内に占める領域情報の対応関係を得て前 記識別子と前記識別子に対応する前記領域情報を出力す 10 る構造復元処理と、前記画像情報のレイアウトを認識し て文字情報の含まれる領域である文字プロックを抽出し て前記領域情報に対応する前記文字プロックを出力する レイアウト解析処理と、前記文字プロック内の文字を認 識してテキストデータを出力する文字認識処理と、前記 論理構造を得るとともに前記識別子に対応する文魯要素 位置に前記テキストデータを挿入して構造化文書を得る タグ設定処理をコンピュータに実行させるプログラムを 格納したコンピュータ読取可能な記憶媒体。

ウトを施して印刷可能とする文書画像処理をコンピュー タに実行させるプログラムを格納したコンピュータ読取 可能な記憶媒体において、前記論理構造に対応してあら かじめ定義されたスタイルデータに基づいて構造化文書 にレイアウトを施して第1の印刷イメージに成形すると ともに前記論理構造と前記レイアウト情報の組み合わせ を同定する組み合わせ情報を生成する成形処理と、前記 組み合わせ情報を付加情報とする付加情報作成処理と、 前記第1の印刷イメージに前記付加情報を重畳して第2 の印刷イメージを生成する付加情報重畳処理をコンピュ 30 ータに実行させるプログラムを格納したコンピュータ読 取可能な記憶媒体。

【請求項22】 構造化文書の論理構造とレイアウト情 報の組み合わせを同定する組み合わせ情報が付加情報と して重畳された印刷イメージを読み取る文書画像処理を コンピュータに実行させるプログラムを格納したコンピ ュータ読取可能な記憶媒体において、前記印刷イメージ を読み取り画像情報に変換する読み取り処理と、前記画 像情報から前記付加情報を読み出す付加情報読み出し処 理と、前記付加情報から前記組み合わせ情報を得て予め 40 設定されている前記論理構造と前記レイアウト情報の定 義に基づいて前記構造化文書の文書要素の意味もしくは 構造を識別するための識別子と前記文書要素が前記印刷 イメージ内に占める領域情報の対応関係を得て前記識別 子と前記識別子に対応する前記領域情報を出力する構造 復元処理と、前記画像情報のレイアウトを認識して文字 情報の含まれる領域である文字ブロックを抽出し前記領 域情報に対応する前記文字プロックを出力するレイアウ ト解析処理と、前記文字ブロック内の文字を認識してテ キストデータを出力する文字認識処理と、前記論理構造 50

を得るとともに前記識別子に対応する文書要素位置に前 記テキストデータを挿入して前記構造化文書を得るタグ 設定処理をコンピュータに実行させるプログラムを格納 したコンピュータ読取可能な記憶媒体。

6

. 【発明の詳細な説明】

[0001]

【発明の属する技術分野】本発明は、構造化文書をプリ ントする際に論理構造とレイアウト構造に関する情報を 可視または不可視に理め込み、また、そのような論理構 造とレイアウト構造に関する情報が埋め込まれた文書の 再入力の際に読み出された論理構造とレイアウト構造を 用いて構造化文書を生成する文書画像処理装置、文書画 像処理方法、および、そのような文書画像処理をコンピ ュータに実行させるプログラムを格納したコンピュータ 読取可能な記憶媒体に関するものである。

[0002]

【従来の技術】電子的に作成された文書の異機種間での 交換、再利用、検索、コンピュータによるデータの解釈 などの用途に、構造化文書の利用が期待されている。代 【請求項21】 論理構造を持った構造化文書にレイア 20 表的な構造化文書としては、ISO8879の標準一般 化マーク付け言語 (SGML:Standard Ge neralized Markup Languag e)が知られている。また、近年では、SGMLのサブ セットにインターネット向けの機能を追加したXML (eXtensible Markup Langua ge)が注目を集めており、企業間の電子商取引の交換 フォーマットとしても期待されている。

> 【0003】構造化文書では、例えば、文書の表題、 章、節、段落などの文書要素を識別するためにタグと呼 ばれる符号が用いられる。タグは、文書の要素を識別す る名称を"<"と">"で囲んだものであり、文書要素 の前後に開始タグ(〈タグ名〉と表記)と、終了タグ (</タグ名>と表記)が挿入される。開始タグと終了 タグの間には、別の開始タグと終了タグが存在する入れ 子構造となることもある。このように、構造化文書で は、タグを用いることによって、文書の構造や文書を構 成する要素の意味を表現することができる。

> 【0004】タグは、文書の内容によって自由に設定で きるが、文書の作り手と受け手で相互に理解できるもの でなければならない。このため、使用されるタグの集合 が定義されており、この定義を文魯型と呼んでいる。S GMLやXMLではDTD (Document Typ e Definition)と呼ばれる。XML文書で は、DTDを別ファイルとしてファイル名で指定した り、XMし文書中に記述することができる。

> 【0005】図8は、文書型の記述の概要を示す説明図 である。図8に示す各行の記述は要案型宣言と呼ばれ、 例えば1行目では「文書」が「表題」と「本文」から構 成されることを示している。また、2行目では、「表 題」がテキストであることを示している。ここで"#P

CDATA"は、XMLではテキストを表すキーワード として用いられる。さらに、3行目では、「本文」が 「第1章」、「第2章」などから構成されていることを 示している。このようにして文書中に現れるすべてのタ グとともに文書の論理的な構造が定義される。

【0006】一方、構造化文書は、タグ付けされた文書 要素の羅列であり、レイアウトに関する情報は一切持っ ていない。このため、構造化文書をディスプレイ表示し たり、印刷するためには、レイアウトやフォント種別、 フォントサイズなどの文書の体裁を指定したスタイルデ 10 ータを与える必要がある。

【0007】図9は、構造化文書を表示あるいは印刷す る場合の構成例を示す説明図である。図中、31はフォ ーマッタである。フォーマッタ31は、入力される構造 化文書に対し、与えられたスタイルファイルに定義され ているスタイルデータ(レイアウト情報、フォント、文 字サイズ等)を参照してレイアウトを行う。この時、構 造化文書の持つ論理構造に対応付けられた文書の要素 は、ページ内の2次元的な領域の配置(レイアウト構 造) に対応づけられ、画面表示や印刷に用いられるペー 20 文書マーカーとして記録しておくものである。文書マー ジイメージ(以下、印刷イメージと呼ぶ)が生成され る。

【0008】図10は、構造化文書のフォーマットの一 例の説明図である。図10(A)には、タグによって表 現された構造化文書の一例を示している。このような構 造化文書をフォーマット処理することによって、例えば 図10(B)に示すようなページレイアウトを持つ印刷 イメージが得られる。

【0009】構造化文書に特定のレイアウト構造を与え 内容の関連を保持することは可能である。しかし、一旦 プリント出力されたり、表示イメージが画像として取り 込まれると、論理構造は失われてしまう。再び論理構造 を付与するためには、文書要素を選択して対応するタグ を選択するなど、労力が大きかった。

【0010】紙原稿のレイアウト構造に基づいて、論理 構造を抽出する技術としては、例えば特開平10-49 522号公報に開示される「文書認識装置」(以下、文 献1と記す)がある。この技術は、OCRの認識結果か ら文書の構造上の特徴を把握し、DTD (Docume 40 nt Type Definition:文書型定義情 報)を自動的に作成する。もしくは既にあるDTDで使 用可能なものを利用する。例えば、原稿を走査して、用 紙の最初に現れる中央寄せされた語句は用紙の表題、と 判断するなど、あらかじめ文書のレイアウトを想定した ルールを持ち、これに従ってDTDを作成するするもの である。

【0011】また同様の技術として、例えば特開平11 - 328306号公報に開示される「文書画像の論理要 **索抽出方法、装置および記録媒体」(以下、文献2と記 50 く。そして、文書のイメージを再入力する際に、これら**

す)がある。これは、あらかじめ複数のサンプル画像を 用いて、論理構造と対応付けられたレイアウトの論理モ デルを作成する。入力された文書のレイアウト構造を抽 出して、論理モデルとの特徴マッチングを行い、もっと も近い論理モデルを用いて入力文書の書誌的事項を抽出 するものである。

8

【0012】これら文献1または文献2に記載されてい るような従来技術では、あらかじめ対象原稿のレイアウ トが既知である必要があり、想定外の原稿が入力された 場合には、論理構造の抽出ができないという問題があっ

【0013】一方、紙文書を入力して、レイアウトや文 字の認識を行う場合に、その認識精度を高めるため、紙 文書中に可視もしくは不可視の情報を埋め込んでおく技 術として、例えば特開平7-168912号公報に開示 される「プリント文書の光学的文字認識能力強化方法及 びその手段」(以下、文献3と記す)がある。これは、 レイアウト解析、OCRの結果に対してエラーの発生や 発生場所を検出したり、エラーを訂正するための情報を カーを不可視に埋め込むためには、ロゴに隠す、不可視 のインクを用いる、フォーマットへの隠蔽などの手法が 用いられている。

【0014】また、レイアウト時の位置情報を不可視の 情報として埋め込んでおく技術として、例えば特開平2 000-196857号公報に開示されている「印刷装 置、情報読取装置、画像処理装置、画像処理システム、 情報読取方法、及び記憶媒体」(以下、文献4と記す) がある。これは、社名、住所、電話番号などの情報が印 てディスプレイに表示している場合は、論理構造と表示 30 刷されている位置情報を電子透かしとして印刷イメージ に埋め込んでおき、読取時に位置情報を読み出してその 位置から各情報のイメージを取得し、文字認識するもの である。

> 【0015】しかし、これら文献3あるいは文献4に記 載の従来技術は、埋め込まれる情報に論理構造は含まれ ておらず、また、紙文書を再入力した時に再び構造化文 費を得ることを目的とするものではなかった。

> 【0016】以上述べたように、従来技術においては、 構造化文書を紙に出力する際のレイアウトを自由にする と、紙文書を再入力した時に再び論理構造を持つ構造化 文書を得ることが困難であった。また、文書を再入力す る際の認識精度を高めるために、文書に付加情報を可 視、もしくは不可視に埋め込む技術はあったが、文書の 論理構造に着目したものはなかった。

[0017]

【発明が解決しようとする課題】本発明は、上述した事 情に鑑みてなされたもので、構造化文書を印刷可能なイ メージとする際に、論理構造とレイアウト構造に関する 情報を、可視もしくは不可視の情報として埋め込んでお

の埋め込まれた情報を用いて構造化文書を得ることのできる、文書画像処理装置および文書画像処理方法、並びに記憶媒体を提供することを目的とするものである。

【課題を解決するための手段】本発明は、論理構造を持った構造化文書にレイアウトを施して印刷可能とする際には、論理構造に対応する体裁情報を定義したスタイルデータに基づいて構造化文書にレイアウトを施して印刷処理に適合した第1の印刷イメージに成形するとともに、構造化文書の文書要素の意味もしくは構造を識別す 10 るための識別子と該文書要素が第1の印刷イメージ内に占める領域情報を生成する。そして、論理構造を表す論理構造情報に加えて、構造化文書の文書要素の意味もしくは構造を識別するための識別子と前記文書要素が第1の印刷イメージ内に占める領域情報の対応関係を示す付加情報を生成して、付加情報を第1の印刷イメージに重

畳し、第2の印刷イメージを生成することを特徴とする

ものである。

【0019】また、このような構造化文書の論理構造を 表す論理構造情報に加えて前記構造化文書の文書要素の 20 意味もしくは構造を識別するための識別子と該文書要素 が印刷イメージ内に占める領域情報の対応関係を示す付 加情報が重畳された印刷イメージを読み取る際には、印 刷イメージを読み取って画像情報に変換し、画像情報か ら付加情報を読み出し、付加情報から論理構造情報を得 て論理構造を復元する。それとともに、構造化文書の文 書要素の意味もしくは構造を識別するための識別子と該 文書要素が印刷イメージ内に占める領域情報の対応関係 を得て、識別子と識別子に対応する領域情報を取得し、 画像情報のレイアウトを認識して文字情報の含まれる領 30 域である文字ブロックを抽出する。そして、領域情報に 対応する前記文字プロック内の文字を認識してテキスト データとし、論理構造を得るとともに識別子に対応する 文書要素位置に認識したテキストデータを挿入して構造 化文書を得ることを特徴とするものである。

【0020】より付加情報を減少させるための構成として、論理構造を持った構造化文書にレイアウトを施して印刷可能とする際に、論理構造に対応してあらかじめ定義されたスタイルデータに基づいて構造化文書にレイアウトを施して第1の印刷イメージに成形するとともに、論理構造と前記レイアウト情報の組み合わせを同定する組み合わせ情報を生成して付加情報とし、該付加情報を第1の印刷イメージに重畳して第2の印刷イメージを生成することができる。

【0021】また、このような構造化文書の論理構造と されるタグの対応を所定の形式に記述して作 レイアウト情報の組み合わせを同定する組み合わせ情報 成する。付加情報重量部5は、フォーマックが付加情報として重量された印刷イメージを読み取る際 される第1の印刷イメージに、付加情報作成には、印刷イメージを読み取って画像情報に変換し、画 した付加情報を重量して第2の印刷イメージ像情報から付加情報を読み出して付加情報から組み合わ る。印字部6は、付加情報重量部5で付加情せ情報を取得し、予め設定されている論理構造とレイア 50 た第2の印刷イメージを記録紙に印字する。

ウト情報の定義に基づいて構造化文書の文書要素の意味もしくは構造を識別するための識別子と文書要素が前記印刷イメージ内に占める領域情報の対応関係を得て、識別子と識別子に対応する前記領域情報を取得する。そして、画像情報のレイアウトを認識して文字情報の含まれる領域である文字ブロックを抽出し、領域情報に対応する文字ブロック内の文字を認識してテキストデータを取得し、論理構造を得るとともに識別子に対応する文書要素位置に認識したテキストデータを挿入して、構造化文書を得るように構成することができる。

10

【0022】このような構成によって、構造化文書にレイアウトを施した印刷イメージに付加情報を重畳して例えば印刷し、その印刷物のイメージを読み取って付加情報をもとに論理構造を復元して構造化文書を取得することができる。

[0023]

【発明の実施の形態】図1は、本発明の第1の実施の形態を示す構成図である。図中、1はフォーマッタ、2はスタイルデータ記憶部、3はスタイル指示部、4は付加情報作成部、5は付加情報重畳部、6は印字部、7は原稿読み取り部、8は補正処理部、9は付加情報読み出し部、10は構造復元部、11はレイアウト解析部、12はOCR部、13は夕グ設定部である。図1には、構造化文書の論理構造を含む付加情報が重畳された印刷イメージを印刷する側の構成と、そのような印刷物を読み取って構造化文書を復元する側の構成の両方を示している。

【0024】構造化文書を印刷する側の構成としては、 フォーマッタ1、スタイルデータ記憶部2、スタイル指 示部3、付加情報作成部4、付加情報重畳部5、印字部 6 等を有している。フォーマッタ1は、入力される構造 化文書に対し、スタイルデータ記憶部2から与えられた スタイルデータ(レイアウト情報、フォント、文字サイ ズ等)に従ってレイアウトを行う。この時、構造化文書 の持つ論理構造に対応付けられた文書の要素は、ページ 内の2次元的な領域の配置(レイアウト構造)に対応づ ・けられ、第1の印刷イメージが生成される。 スタイルデ ータ記憶部2は、1ないし複数のスタイルデータを記憶 しており、スタイル指示部3から指示されたレイアウト 40 データをフォーマッタ1に出力する。スタイル指示部3 は、利用者がスタイルデータ記憶部2に記憶されている スタイルデータの選択及び編集を行う。付加情報作成部 4は、フォーマッタ1から出力される第1の印刷イメー ジ内の2次元の領域情報と、構造化文書の文書型に定義 されるタグの対応を所定の形式に記述して付加情報を作 成する。付加情報重畳部5は、フォーマッタ1から出力 される第1の印刷イメージに、付加情報作成部4で作成 した付加情報を重畳して第2の印刷イメージを生成す る。印字部6は、付加情報重畳部5で付加情報を重畳し

【0025】また構造化文書を復元する側の構成として は、原稿読み取り部7、補正処理部8、付加情報読み出 し部9、構造復元部10、レイアウト解析部11、OC R部12、タグ設定部13等を有している。原稿読み取 り部7は、印字部6によって印刷された紙文書の画像を 読み取る。補正処理部8は、原稿読み取り部7で読み取 られた画像情報に対して、スキュー補正や、天地補正な どの補正処理を行う。付加情報読み出し部9は、画像情 報に重畳されている付加情報を読み出す。構造復元部1 0は、付加情報読み出し部9によって読み出された付加 10 情報から、論理構造とレイアウト構造に関する情報を復 元する。レイアウト解析部11は、読み取られた原稿の レイアウトを解析して、構造復元部10が出力するレイ アウト構造を参照して文字ブロックを切り出す。OCR 部12は、切り出された文字プロックごとにOCR (文 字認識)を施し、テキスト情報を出力する。タグ設定部 13は、OCR部12から出力されたテキスト情報を、 構造復元部10から出力されるタグの対応する箇所に挿 入し、構造化文書を出力する。

【0026】図2は、タグ設定部13の一例を示す構成 20 図である。図中、21は論理構造保持部、22はタグ記 憶部、23は夕グ開始終了判定部、24は切替部であ る。論理構造保持部21は、構造復元部10で復元され た文魯の論理構造(タグの入れ子構造)を記憶する。タ グ記憶部22は、構造復元部10からレイアウト解析部 11に領域情報を送るのと同期して出力されるタグ情報 を保持する。タグ開始終了判定部23は、論理構造保持 部21から順次出力される文書の論理構造からタグ記憶 部22に記憶されるタグの開始と終了を検出して切替部 24の入力を切り替える。切替部24は、タグ開始終了 30 判定部23の指示により論理構造保持部21から出力さ れるタグとOCR部12から出力されるテキストデータ の何れかを切り替えて出力し、文書構造中にテキストデ ータを挿入する。

【0027】本発明の第1の実施の形態における動作に ついて説明する。構造化文書はフォーマッタ1に入力さ れる。なお、図1においては構造化文書と文書型が別フ ァイルとして構成されているものとして示しており、文 書型は付加情報作成部4によって読み込まれるととも に、構造化文書内においてファイル名などで指定され、 参照される。一方、スタイル指示部3において利用者が 構造化文書を印刷する際に用いるスタイルデータの選択 指示を行い、指示されたスタイルデータがスタイルデー 夕記憶部2からフォーマッタ1に入力される。なお、ス タイルデータは、スタイルデータ指示部3によって利用 者が設定を変更することができる。

【0028】フォーマッタ1は、スタイルデータ記憶部 2に記憶されている選択されたスタイルデータに基づい て、入力された構造化文書から印刷イメージを形成す る。そして、構造化文書の文書型と、文書要案に対応づ 50 領域の対応の記述の別の例の説明図である。タグと、印

けられたタグとこの文書要素が印刷イメージ内に占める 2次元領域の対応を示す情報を付加情報作成部4に送る とともに、フォーマットされた印刷イメージを付加情報 重畳部5に送る。

12

【0029】図3は、印刷イメージ内のレイアウトを構 成する2次元領域の設定方法と2次元領域の記述方法の 一例の説明図である。例えば文書作成ソフトウェアのテ キストポックスなどのように、文書画像のレイアウトで は矩形領域を基本とすることが多い。また、文書認識の 前処理としてレイアウト解析を行う場合には、原稿内の 文字の領域を文字プロックと呼ばれる矩形の領域として 抽出することが多い。このため、本発明では文書画像の レイアウトは、矩形領域の2次元の配置情報と考える。 【0030】図3(A)は、図10(B)に示したペー ジレイアウトを持つ印刷イメージに対し、印字要素に外 接する矩形領域を設定したものである。それぞれの矩形 領域の各辺が用紙端と平行であるものとし、原稿の最左 上端を原点とし、水平方向をx軸、垂直方向をy軸とす る座標系を設定する。これにより、印刷イメージ内の矩 形領域は、最左上の角を開始座標(x,y)、矩形領域 の幅(x軸方向)をw、矩形領域の高さ(y軸方向)を hで表現することができる。図3(A)に示すページレ イアウト内に表示される文書要素に対応する2次元領域 は、図3(B)に示すように記述される。レイアウトを 構成する矩形領域の位置と大きさは、スタイルデータに 基づいてフォーマッタ1によって決定される。矩形領域 の位置と大きさが、原稿内の座標系に対して固定である 場合と、例えば、フォントサイズや段落幅の変更に対応 して変更される場合がある。

【0031】なお、本発明においては、矩形領域の記述 方法はこれに限定されるものではなく、矩形領域の4端 点の座標を用いるなど他の記述方法を用いても構わな い。また、座標系の単位についても限定されるものでは なく、ミリメートル単位やインチ単位、その他の単位を 用いてもかまわない。また、原稿サイズで正規化した座 標系の単位を用いてもかまわない。

【0032】付加情報作成部4では、文書型と、タグと 印刷イメージ内の2次元領域の対応関係を所定の記述形 式で生成し、付加情報として付加情報重畳部5に送る。 40 図4は、タグと、印刷イメージ内の2次元領域の対応の 記述の一例の説明図である。最も単純な記述方法は、タ グの名称と矩形領域の情服を対で記述する方法である。 同じ文書内に同一の名称を持つタグが存在する場合は、 上位の階層のタグから記述することでそれぞれを識別で きるようにする。例えば、〈段落1〉のタグだけではど の章の段落かを判別できない場合には、上位の階層を示 す<第1章>のタグとともに記述して区別すればよい。 図4においては、階層を'/'で区切って示している。 【0033】図5は、タグと、印刷イメージ内の2次元

14

刷イメージ内の2次元領域の対応の記述として、例えば図5に示すように記述することもできる。この例では、図10(A)に示したようにタグを用いて表現された文書の論理構造において、開始タグと終了タグに囲まれる部分から文書要素を取り除き、代わりに対応する矩形領域の情報を理め込むものである。このような操作によって、例えば図5(A)に示すような記述を得ることができる。この場合には、先の例のように同一名称のタグが存在する場合でも、一対一にレイアウト構造との対応づけを表現することができる。

【0034】ただし、図5(A)に示す記述では、文書型とともに付加情報として追加するには、表現が冗長である。このため、図5(A)に示した表記に対し、例えば、開始タグと終了タグをそれぞれ開き括弧と閉じ括弧で置き換え、タグ名称を除去することによって、図5(B)に示すような記述を得ることができる。さらに、

(B) に示すような記述を得ることができる。さらに、 改行やインデンテーションは、人が見る時の理解を容易 にするためのものであり、これらはタグ(図5 (B) で は括弧に置き換えられている)の入れ子関係から階層構 造を把握する上では不要であり、実際に埋め込まれる情 20 報からは除外することができる。このようにして、図5

(C) に示す記述が得られる。この記述を文書型ととも に付加情報とすることができる。なお、この例では階層 構造の表記に丸括弧を用いたが、これに限られるもので はなく、種々の表記が可能である。

【0035】付加情報重畳部5では、付加情報作成部4で作成された、論理構造とレイアウト構造の対応の記述を、フォーマッタ1によって生成された印刷イメージに付加情報として重畳する。印刷イメージへの情報の重畳方法としては、人の目に見える形式(可視)で埋め込む場合と、人の目には見えない、もしくは、見えづらい形式(不可視)で埋め込む場合がある。文書に可視に情報を埋め込む技術としては、バーコードやグリフコードを用いるなどの公知の手法を適用することができる。なお、可視に情報を埋め込む場合には、あらかじめフォーマッタ1において印刷イメージを形成する際に、用紙内に情報を埋め込むための領域を確保しておくとよい。

【0036】一方、文書に不可視に情報を埋め込む技術としては、例えば特開2000-138813号公報に開示される「画像処理装置および画像処理方法」(以下、文献5と記す)などの技術が適用可能である。この他にも、不可視なインク、トナー等を用いて情報を埋め込む方法等も適用可能である。

【0037】付加情報重量部5によって論理構造とレイアウト構造の対応の記述が埋め込まれた印刷イメージは、印字部6によって用紙に記録される。以上の構成と動作により、構造化文書にその構造情報を含む付加情報を重畳して印刷することができる。

【0038】次に、このようにして印刷された紙原稿を 析部11に送り、OCR部12により認識処理を行う文 読み取り、構造化文書を復元する際の処理について説明 50 字ブロックを通知するとともに、対応するタグをタグ設

してゆく。原稿読み取り部7は、紙原稿を走査してラスタ画像データを生成し、補正処理部8においてラスタ画像データに対する補正処理を実行し、補正されたラスタ画像データを付加情報読み出し部9に入力する。補正処理の内容としては、紙原稿が傾いて読み込まれた場合のスキュー補正や、天地が逆転して読み込まれた場合の天地補正などがあり、それぞれについての公知の手法を適用することができる。

【0039】付加情報読み出し部9は、紙原稿に重畳されている付加情報を読み出す。読み出す方法は、付加情報重畳部5における情報の重畳方法に対応した方法を用いればよい。例えばバーコードやグリフコードによって情報が可視に埋め込まれている場合は、これらの情報を読み取って元の情報に復元する公知の手法を利用すればよい。また、上述の文献5に示されている手法によって不可視に情報が埋め込まれている場合についても、同文献に記載されている読み出し方法によって読み出せばよい。この他、不可視なインク、トナー等を用いて情報が埋め込まれた場合についても同様である。付加情報読み20出し部9によって読み出された付加情報は構造復元部10に入力され、それ以外のラスタ画像情報はレイアウト解折部11に入力される。

【0040】構造復元部10では、論理構造と、論理構造とレイアウト構造の構成要素の対応関係が復元される。上述のように、付加情報としては、文書型と、タグと印刷イメージ内の2次元領域の対応関係が得られる。タグと印刷イメージ内の2次元領域の対応関係としては、例えば図4に示すようなデータ、あるいは図5

(B) または (C) に示すようなデータが得られるの で、これらの論理構造の情報と文書型とを対比すること によって論理構造を復元することができる。図6は、復 元された論理構造の一例の説明図である。図6は、図4 あるいは図5(B)又は(C)に示した論理構造とレイ アウト構造の対応関係に基づいて、文書型から論理構造 を復元した例を示している。図4に示した論理構造とレ イアウト構造の対応関係の情報を用いる場合には、それ ぞれのタグ名が含まれているので、文書型における構成 要素との対応付けを行うことによって論理構造を復元す ることができる。また、図5(B)又は(C)に示した 40 論理構造とレイアウト構造の対応関係の情報を用いる場 合には、論理構造の入れ子関係が分かるので、文書型と の対応付けによって各タグ名を特定することができる。 なお、構造復元部10において文書型に基づいて復元さ れた論理構造は、図6に示しているようにタグの階層構 造だけを持つもので、内容は含まれない。この論理構造 は、タグ設定部13に送られる。

[0041]また、構造復元部10は、レイアウト構造を構成する矩形領域の記述情報を、順次、レイアウト解析部11に送り、OCR部12により認識処理を行う文字プロックを通知するとともに、対応するタグをタグ設

定部13に通知する。

【0042】一方、レイアウト解折部11では、ラスタ画像データ中から、文字プロックや写真などの絵柄領域を、矩形領域を単位として検出する。これらの矩形領域の内、構造復元部10から受け取った矩形領域情報に対応するラスタ画像データの部分領域をOCR部12に送り、OCR部12によって文字認識処理が施される。得られたテキストコード情報がタグ設定部13に送られる

【0043】タグ設定部13では、文書型などによりあ 10 らかじめ設定されている論理構造の雛形に対し、構造復元部10より通知されるタグに対応する位置に、OCR部12から送られるテキストデータを設定して構造化文書を復元する。

【0044】このタグ設定部13における動作を、図2を用いて説明する。はじめに、構造復元部10で復元された文書の論理構造は、タグ設定部13内の論理構造保持部21に記憶される。次に構造復元部10によって、レイアウト構造に対応を持つタグの内、論理構造内で最も先頭に近いタグがタグ記憶部22に設定される。これ 20に同期して、構造復元部10では設定されたタグに対応する領域情報をレイアウト解析部11に送出する。

【0045】タグ開始終了判定部23は、論理構造保持部21から順次出力されるタグを監視し、タグ記憶部22に記憶されているタグの開始タグが検出されるまで、論理構造保持部21の出力がそのまま出力されるように切替部24を制御する。タグ開始終了判定部23が論理構造保持部21の出力からタグ記憶部22に記憶されるタグの開始タグを検出すると、この開始タグの出力後に切替部24の入力をOCR部12の出力に切り替える。OCR部12では、構造復元部10からレイアウト解析部11に出力された領域情報に対応する読み取り画像内の文字認識処理が行われてテキストデータとして出力される。このテキストデータが切替部24に入力され、そのまま出力されることになる。

【0046】OCR部12によるテキストデータの出力終了が図示しない制御信号によってタグ開始終了判定部23に通知され、切替部24の入力を論理構造保持部21に切り替える。論理構造保持部21からは、タグ記憶部22に記憶されているタグの終了タグが出力される。この時、構造復元部10からは、レイアウト構造に対応を持つタグの内、前記論理構造内で先頭から2番目のタグがタグ記憶部22に設定される。これに同期して、構造復元部10では新たに設定されたタグに対応する領域情報をレイアウト解析部11に送出する。

【0047】以上の動作を繰り返すことにより、文書型より生成された論理構造に対し、タグに対応づけられた文書領域のOCR結果が順次挿入されることになる。このようにして、読み取られた紙文書から構造化文書を復元することができる。

【0048】上述の例では、文書型は必ず付加情報として重畳しているが、これを簡略化することで情報量を減少することもできる。例えば、XMLを企業間の電子商取引に応用する場合などでは、あらかじめ関係する企業間において取引内容に基づく文書型(DTD)が標準化されていくと考えられる。このように、構造化文書を印刷する側と読み取る側で、文書型についての情報が共有

されている場合は、必ずしも文書型を理め込む必要はな く、文書型を特定できる情報を埋め込んだり、あるいは

16

【0049】また、複数の構造化文書を1枚の用紙にまとめて出力する場合には、文書型とともに、タグと矩形領域の対応を示す情報の埋め込みを、構造化文書の数だけ繰り返せば良い。

文書型の情報を埋め込まなくてもよい。

【0050】次に、本発明の第2の実施の形態について 説明する。情報を埋め込む場合には、埋め込まれる情報 の量を考慮する必要がある。例えば、バーコードを用い て情報を可視に埋め込む場合に情報量が多いと、原稿上 のパーコードを印刷する面積を大きくする必要があり、 本来の文書内容の印刷領域に制限が生じることが考えられる。この本発明の第2の実施の形態は、このようお問題に鑑みてなされたものであり、構造化文書の論理構造と印刷時のレイアウト構造を対応付ける情報をより少ない情報量で表現しようとするものである。なお、構成は 上述の第1の実施の形態とほぼ同様であるので、上述の 図1及び図2を参照するものとして相違点について主に 説明してゆく。また、動作についても、同様の動作については説明を省略する。

【0051】上述の第1の実施の形態においては、レイ 30 アウト構造を構成する領域情報を形領域の開始座標

(x, y), 幅(w), 高さ(h)で表現していた。しかし、印刷時と読み取り時に原稿内の矩形領域に同一の識別子を割り当てることができれば、領域情報を表す情報量を削減することができる。例えば、上述の図3

(A)に示したページレイアウトにおいて、印刷イメージを原点から走査してゆき、矩形領域の開始座標が現れる順序に1から5の識別子を割り当てることが考えられる。印刷時は、付加情報作成の際に、レイアウト構造を構成する2次元領域に一意に識別子として番号を割り振ることができる。また、原稿を読み取る側では、レイアウト解析により検出された矩形領域に対して、同様の手順で識別子の番号を割り振ればよい。このとき、印刷時と読み取り時で同じ矩形領域については識別子が同じになるように、識別子の割り振りを行い、またレイアウト解析を行えばよい。

【0052】図7は、本発明の第2の実施の形態におけるタグと印刷イメージ内の2次元領域との対応の記述の一例の説明図である。ここでは、図7(A)、(B)に示した2つの異なるレイアウト構造を考える。上述のように矩形領域の開始座標が現れる順序(この例では水平

方向優先)に従って識別子を割り当てると、図7 (A), (B) において数字で示すように各矩形領域に 識別子を割り当てることができる。

【0053】いま、図7(C)に示すような論理構造を

もつ構造化文書があり、タグC1, C2, C3で定義さ れる内容を、図7(A),(B)に示すレイアウト構造 に従ってフォーマットする。これによってタグС1, С 2, C3で定義される内容は、それぞれ、例えば図7 (E), (F)に示すように割り当てることができる。 の記述は、上述の第1の実施の形態における図4に示し た例と同様に、タグと識別番号を対で記述する方法がも っとも単純である。図7(G),(H)は、それぞれ図 7 (E), (F) に対応する。例えば図7 (E) に示す ようにタグC1の内容は矩形領域1に配置され、タグC 2の内容は矩形領域2に配置され、タグC3の内容は矩 形領域3に配置されている。この関係を図7(G)に示 すように表記すれば、論理構造と矩形領域との対応を記 述することができる。同様に、図7(F)に示すように タグC1の内容は矩形領域1に配置され、タグC2の内 20 容は矩形領域3に配置され、タグC3の内容は矩形領域 2に配置されている場合には、この関係を図7 (H) に 示すように表記すれば、論理構造と矩形領域との対応を

【0055】なお、図7(G), (H)における「ID =N」の部分は、図7(C)に示した文書構造がNとい うID(識別子)で管理されている場合の簡略表記であ る。この場合、印刷時と印刷物の読み取り時で同じID で文書構造が管理されていることを前提となる。もちろ ん、上述の第1の実施の形態と同様に、この部分に文書 30 型を設定してもよい。

記述することができる。

【0056】また、やはり上述の第1の実施の形態にお いて図5で説明した例と同様に、図7(C)に示した論 理構造は、図7(D)に示すように括弧を用いた簡略表 現が可能であり、タグを除去した後にタグに対応する文 費内領域の識別番号を挿入して論理構造とレイアウト構 造の対応を記述することができる。この場合、図7

(E), (F)に対応する記述は、それぞれ図7

(I), (J)に示すようになる。このような記述によ って、付加情報を、文書型と、タグと識別番号の対応付 40 の記述の一例の説明図である。 けによって、より少ない情報量で簡略に記述することが

【0057】上述の第1及び第2の実施の形態では、構 造化文書の論理構造と印刷時のレイアウト構造との組み 合わせが任意である場合に適用可能である。しかし、論 理構造(文書型)に対応するレイアウト構造の組み合わ せが一意に定まるとともに、構造化文書を印刷する側と 読み取る側においてこの組み合わせについての情報が共 有される場合には、これらの組み合わせを指定する情報 を付加情報として埋め込むことができる。この場合、論 50

理構造とレイアウト構造の対応を示す情報量を格段に少 なくすることができる。

【0058】なお、上述の第1及び第2の実施の形態で は、印字部6によって構造化文書及び付加情報を紙に記 録する場合について述べたが、これに限らず、例えば付 加情報を含む構造化文書のイメージをファイルなどに保 存しておき、このイメージを読み出して構造化文書を復 元する場合にも、同様にして本発明を適用可能である。 【0059】上述の各実施の形態やその変形及び組み合 【0054】この時、論理構造とレイアウト構造の対応 10 わせは、コンピュータプログラムによっても実現するこ とが可能である。その場合、そのプログラムおよびその プログラムが用いるデータなどは、コンピュータが読み 取り可能な記憶媒体に記憶することも可能である。記憶 媒体とは、コンピュータのハードウェア資源に備えられ ている読取装置に対して、プログラムの記述内容に応じ て、磁気、光、電気等のエネルギーの変化状態を引き起 こして、それに対応する信号の形式で、読取装置にプロ グラムの記述内容を伝達できるものである。例えば、磁 気ディスク、光ディスク、CD-ROM、メモリカー

[0060]

【発明の効果】以上の説明から明らかなように、本発明 によれば、構造化文書を出力する際に、文書のレイアウ ト構造と論理構造に関する情報を、可視、または、不可 視の情報として埋め込むことにより、再入力の際には埋 め込まれているレイアウト構造と論理構造に関する情報 に基づいて、再び構造化文書を得ることができる。ま た、文書のレイアウト構造と論理構造に関する情報から 構造化文書を復元するので、構造化文書の出力時のレイ アウト設定の自由度を大幅に向上させることができると いう効果がある。

ド、コンピュータに内蔵可能なメモリ等である。

【図面の簡単な説明】

【図1】 本発明の第1の実施の形態を示す構成図であ

【図2】 タグ設定部13の一例を示す構成図である。

【図3】 印刷イメージ内のレイアウトを構成する2次 元領域の設定方法と2次元領域の記述方法の一例の説明 図である。

【図4】 タグと、印刷イメージ内の2次元領域の対応

【図5】 タグと、印刷イメージ内の2次元領域の対応 の記述の別の例の説明図である。

【図6】 復元された論理構造の一例の説明図である。

【図7】 本発明の第2の実施の形態におけるタグと印 刷イメージ内の2次元領域との対応の記述の一例の説明 図である。

【図8】 文書型の記述の概要を示す説明図である。

【図9】 構造化文書を表示あるいは印刷する場合の構 成例を示す説明図である。

【図10】 構造化文書のフォーマットの一例の説明図

【符号の説明】

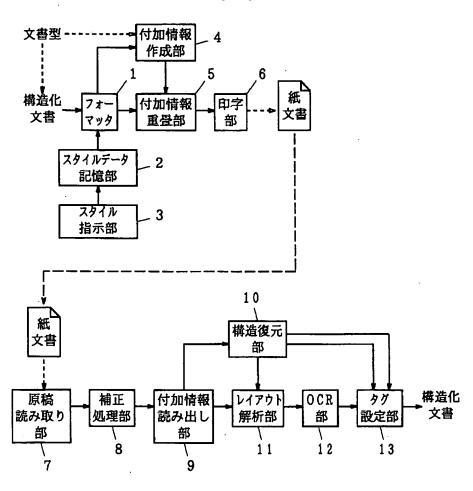
である。

1…フォーマッタ、2…スタイルデータ記憶部、3…スタイル指示部、4…付加情報作成部、5…付加情報重登部、6…印字部、7…原稿読み取り部、8…補正処理

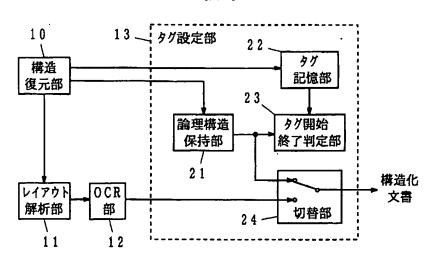
19

部、9…付加情報読み出し部、10…構造復元部、11 …レイアウト解析部、12…OCR部、13…タグ設定 部、21…論理構造保持部、22…タグ記憶部、23… タグ開始終了判定部、24…切替部、31…フォーマッタ。

【図1】



[図2]



[図3]

(B)

領域1 開始座標 (x₁,y₁),幅 (w₁),高さ (h₁) 領域2 開始座標 (x₂,y₂),幅 (w₂),高さ (h₂) 領域3 開始座標 (x₃,y₃),幅 (w₃),高さ (h₃) 領域4 開始座標 (x₄,y₄),幅 (w₄),高さ (h₄) 領域5 開始座標 (x₅,y₅),幅 (w₅),高さ (h₅) 【図4】

表題: (x₁,y₁,w₁,h₁) 章題: (x₂,y₂,w₂,h₂) 第1章/段落1: (x₃,y₃,w₃,h₃) 第1章/図/データ1: (x₄,y₄,w₄,h₄) 第1章/図/図題1: (x₅,y₅,w₅,h₅)

[図6]

```
      〈文書〉

      〈表題〉
      〈本文〉

      〈第1章〉
      〈章題1〉
      〈段落1〉

      〈段落1〉
      〈/段落1〉

      〈四〉
      〈/面〉
      〈/面〉

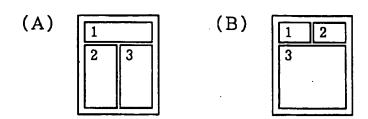
      〈/本文〉
```

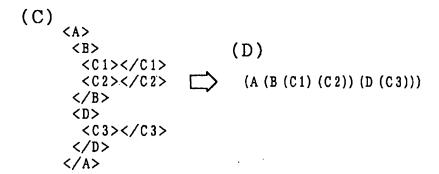
[図8]

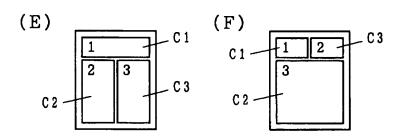
【図5】

```
((x_1,y_1,w_1,h_1)\ (((x_2,y_2,w_2,h_2)\ ((x_3,y_3,w_3,h_3))\ \cdots\ ((x_4,y_4,w_4,h_4)\ (x_5,y_5,w_5,h_5)))\ \cdots))
                                                                                                                                      (x3, y3, w3, h3)
                                                                                                                                                                                                                                   (x5, y5, w5, h5)
                                                                                                                                                                                                                  (x4, y4, w4, b4)
                                                                                                 (x2, y2, w2, h2)
(B)
                                                                                                                                                                                                                  \langle \vec{\tau} - \beta \rangle > (x_4, y_4, w_4, h_4) \langle /\vec{\tau} - \beta \rangle
                                                                                                                                                                                                                                   <図題1>(x5,y5,w5,h5)</図題1>
                                                                                                   <章題1> (x2, y2, w2, h2) </章題1>
                                                                                                                                        (x_3, y_3, w_3, h_3)
                                              <表題> (x |, y |, w |, b |) </ 表題>
                                                                                                                                                          </段格1>
                                                                                                                     〈段落1〉
                                                                                                                                                                                                                                                      ⟨⊠
⟨⊠
                                                                                                                                                                                                公区
                                                                                                                                                                                                                                                                     </第1章>
                                                                                  〈第1章〉
                                                                                                                                                                                                                                                                                            〈/本次〉
〈/文儘〉
                            〈文書〉
(A)
                                                                                                                                                                                                                                                                                                                                                                     (C)
```

[図7]



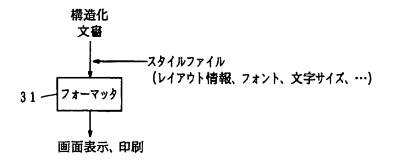




(G)
$$ID=N$$
, $C1=1$, $C2=2$, $C3=3$ (H) $ID=N$, $C1=1$, $C2=3$, $C3=2$

(I)
$$ID=N$$
, $(((1)(2))((3)))$ $ID=N$, $(((1)(3))((2)))$

【図9】



[図10]

```
(A)
      く文書>
       〈表題〉○○〈/表題〉
        〈本文〉
         <第1章>
           〈章題1>△△△</章題1>
           <段落1>
                **
           </段落1>
           <図>
              <アータ1>×××、jpg </データ1>
              <図題1>図1×××</図題1>
           </図>
         </第1章>
        </本文>
       </文書>
                          スタイルデータ
        (B)
               表題〇〇〇
                第1章△△△
                  ***
```

フロントページの続き

H 0 4 N 1/387

(51) Int. C1.7

識別記号

FI

図1 XXX

テーマコード(参考)